

Tomislav Gelo*

UDK 330.567.2:330.43

JEL Classification C53, Q31, D12

Izvorni znanstveni rad

EKONOMETRIJSKO MODELIRANJE POTRAŽNJE ZA PLINOM

U ovome je radu obrađeno ekonometrijsko modeliranje potražnje za plinom, odnosno mjesečna potražnja kućanstava za prirodnim plinom i definiranje funkcije ukupne i prosječne mjesečne potražnje kućanstava za prirodnim plinom. Ukupna i prosječna mjesečna potrošnja plina ovisne su varijable, a srednja mjesečna temperatura zraka, cijena prirodnoga plina za kućanstva i prosječna plaća neovisne su varijable.

Energija kao i funkcija potražnje za njom veoma su važni za funkcioniranje cjelokupne privrede svake države, pa tako i Hrvatske. U trenutku kada važnost energije sve više raste zanimljivo je vidjeti koji su to čimbenici koji utječu na potražnju za energijom i kolika je važnost pojedinog čimbenika.

U radu se regresijskom analizom definira funkcija potražnje za prirodnim plinom. Utvrđeno je da potražnja za prirodnim plinom primarno ovisi o srednjoj mjesečnoj temperaturi zraka, a da je utjecaj ostalih varijabli, cijena energenta za kućanstva i prosječne plaće, znatno manje signifikantan. Stoga se može zaključiti da je potražnja za prirodnim plinom neelastična ili je veoma malo elastična na promjene cijene prirodnoga plina i prosječne plaće. Također se pokazalo da ekonometrijski modeli u kojima je prosječna mjesečna potrošnja prirodnoga plina ovisna varijabla bolje opisuju stvarnost od modela u kojima je ovisna varijabla ukupna potrošnja prirodnoga plina.

Konačno, izabrani model u kojem je prosječna mjesečna potrošnja prirodnoga plina ovisna varijabla prihvatljiv je ne samo kao model koji opisuje ponašanje kućanstava u potrošnji, nego i kao model za predviđanje buduće potražnje za prirodnim plinom zbog varijacija neovisne varijable.

Ključne riječi: ekonometrijska analiza, funkcija potražnje za prirodnim plinom, cijena prirodnoga plina, prosječna plaća, prosječna mjesečna temperatura zraka

* T. Gelo, mr. sc., asistent na Ekonomskom fakultetu Sveučilišta u Zagrebu. Prva verzija članka primljena 3. 12. 2004; konačna verzija primljena 5. 1. 2006.

1. Determinante ponude i potražnje za prirodnim plinom

Na promjene potrošnje pojedinih energenata, osim cijene, utječu i promjene dohotka građana, promjene broja stanovnika, promjene cijena komplemenata i supstituta pojedinih energenata i promjene cijena ostalih dobara. Temperatura zraka i promjene temperature zraka svakako su najvažnija odrednica potrošnje plina u kućanstvima.

Kada se govori o veličini ponude, na nju utječu promjene cijena inputa za proizvodnju energije, zatim promjene u tehnologiji proizvodnje i promjene u standardima zaštite okoliša.

Kada je, međutim, riječ o ponudi prirodnoga plina na energetsom tržištu Hrvatske situacija je takva da za kategoriju kućanstva plina bez obzira na potrošene količine vrijedi gotovo uvijek ista cijena, što ukazuje na deformacije tržišnih odnosa. Drugi je važan faktor kod ponude plina u Hrvatskoj to da plina za kućanstva uvijek ima, odnosno da plina za kućanstva uvijek mora biti dovoljno bez obzira na potražnju, a to znači da kućanstva uvijek imaju prednost u opskrbi plinom. Zbog navedenih je razloga krivulja ponude plina vodoravna, odnosno savršeno elastična.

U konkurentskim i razvijenim tržištima cijenu energije, pa tako i cijenu plina, prije svega određuju ponuda i potražnja. U svakom trenutku tržišna cijena plina ovisi o graničnom potrošaču i o graničnom dobavljaču plina. U slučaju monopola zbog nepostojanja konkurencije dolazi do diskriminacije potrošača zbog različitih elastičnosti potražnje na cijenu na različitim tržištima.

Ponuda i potražnja u kratkom i dugom roku

U kratkome roku na potražnju za prirodnim plinom na tržištu utječu slijedeće odrednice:

- Klima je osnovna odrednica kućanstva za prirodnim plinom u kratkome roku;
- Sezonalnost potražnje za plinom u termoelektranama za proizvodnju električne energije i stupanj podudarnosti vršne potražnje za plinom i električnom energijom;
- Vršna potrošnja - zahtjevi dobavljača za transportom plina u skladište, koji je u funkciji vršne potražnje za plinom, što ovisi o očekivanjima cijene plina u budućnosti;
- Supstitutivnost koja pokazuje ne samo tehničku mogućnost krajnjih potrošača da promjene energent u kratkome roku, već i odnose cijena

konkurentnih energenata. U većini zemalja malo potrošača ima tehničku mogućnost da u kratkome roku promijeni tip energenta. Za to je obično potrebno nekoliko godina, odnosno dok se tehnički ne osposobe mogućnosti korištenja alternativnog energenta. Veliki industrijski potrošači najčešće imaju mogućnost upotrebe alternativnih goriva u svojim postrojenjima. Cijene konkurentskih energenata utječu na krivulju potražnje za tim energentom.

Dugoročna ponuda plina u konkurencijskim uvjetima ovisi o dugoročnom graničnom trošku proizvodnje.

Dugoročan granični trošak proizvodnje, koji uključuje troškove istraživanja i razvitka i troškove održavanja, ovisi o:

- izvoru,
- komplementarnosti - je li plin proizveden u kombinaciji sa sirovom naftom, što smanjuje troškove istraživanja,
- tehnologiji - stanje postojeće tehnologije kao i razvitka nove,
- organizaciji - organizacijska efikasnost, uključujući unutarnju proizvodnost i suradnju između proizvođača.

Potražnja za plinom u dugom roku rezultat je niza čimbenika, među kojima se posebno ističu i ekonomski rast gospodarstva, cijene konkurentnih goriva, tehnologija, ekološka ograničenja pri uporabi energije.

Hrvatsko tržište potražnje za prirodnim plinom

Potražnja kućanstava za prirodnim plinom u Republici Hrvatskoj uzeta je s pretpostavkom da plina uvijek ima dovoljno da zadovolji trenutnu potražnju za plinom. Hrvatska oko 40% ukupne potražnje za plinom podmiruje uvozom, a 60% domaćom proizvodnjom. Zanimljivo je analizirati potražnju za plinom u Hrvatskoj, odnosno u Zagrebu, i procijeniti relativnu važnost svih mjesečnih determinanti. Zagreb je odabran za analizu ne samo zbog toga što potrošnja plina u Zagrebu čini oko 1/3 ukupne potrošnje plina u Republici Hrvatskoj, nego i zbog toga što za analizu potražnje u Zagrebu postoje svi potrebni podaci i istovremeno konkurentnost između energenata.

Od nabrojanih determinanti potražnje za plinom u radu se analizira utjecaj samo onih determinanti na veličinu potražnje za koje se pretpostavlja da najviše utječu na potražnju. To su: temperatura zraka, prosječna plaća i cijena prirodnoga plina.

2. Varijable korištene u modelu

Kod modeliranja potražnje za plinom primijenjena je regresijska analiza. Cilj je analize testirati tvrdnju da potražnja za prirodnim plinom ovisi o tri navedene varijable i procijeniti važnost utjecaja pojedinih varijabli na potražnju. Testiranje veze između ovisne varijable i objasnidbenih varijabli provedeno je na reprezentativnom vremenskom nizu podataka.

Provedene su dvije različite analize. U prvoj je ovisna varijabla ukupna potražnja za plinom u Zagrebu, a u drugom je slučaju ovisna varijabla prosječna mjesečna potražnja za plinom. Kada se kao ovisna varijabla upotrebljava ukupna potrošnja prirodnoga plina, onda nije moguće razdvojiti utjecaj na povećanje potrošnje novih potrošača od utjecaja rasta plaća, promjene vanjske temperature i promjene cijene plina. To je moguće tek onda kada se u model kao ovisna varijabla uvede prosječna potrošnja prirodnoga plina po kućanstvu.

U modelima su kao ovisne varijable upotrebljavane ukupna mjesečna potrošnja prirodnoga plina i prosječna mjesečna potrošnja prirodnoga plina, prosječna mjesečna temperatura zraka u stupnjevima Celzijusa, stupanj dani, prosječna plaća u kunama i cijena plina za kućanstva u kunama po kubičnom metru. U skladu s navedenim varijablama postoje dva modela. U prvome je ukupna mjesečna potražnja za plinom ovisna varijabla, a neovisne su varijable srednja mjesečna temperatura zraka, prosječna plaća i cijena plina. U drugome je modelu prosječna mjesečna potražnja za plinom ovisna varijabla, a neovisne su varijable stupanj dani, prosječna plaća i cijena plina.

Srednja mjesečna temperatura zraka¹

U analizi su uzete u obzir srednje mjesečne vrijednosti temperature zraka u gradu Zagrebu. Podaci su izmjereni na hidrometeorološkoj postaji Maksimir. Pretpostavka je da je utjecaj ove varijable na potrošnju plina značajan i da je temperatura obrnuto proporcionalna potražnji za plinom u kućanstvima. Pretpostavlja se da potražnja za plinom pada kada srednja temperatura raste i obrnuto i da je potražnja za plinom na srednju temperaturu zraka elastična.

¹ Vuk, B et al: "Energija u Hrvatskoj 2000. i 2002.", Godišnji energetske pregled, Ministarstvo gospodarstva, Republika Hrvatska, Zagreb, (poglavlje o meteorološkim podacima).

Stupanj dani²

Stupanj dani češće su korištena varijabla, umjesto srednje dnevne temperature zraka. Kada je srednja dnevna temperatura visoka, broj je stupanj dana mali i obrnuto, kada je srednja dnevna temperatura zraka mala, broj je stupanj dana veliki. Ljeti su stupanj dani nula, odnosno kad je god mjesečna temperatura manja od 18°C, stupanj dani iznose nula.

Ukupna potražnja prirodnoga plina³

Ukupna je potražnja za plinom u Zagrebu najveća u zimskim, a najmanja u ljetnim mjesecima. Potražnja je ljeti veoma ujednačena, a značajna su odstupanja u siječnju i u prosincu. Omjer između potražnje u ljetnim i zimskim mjesecima u prosjeku je 1:9 puta, ili potražnja je zimi 9 puta veća od potražnje ljeti. Ljeti se plin troši samo za kuhanje i za pripremu tople vode, a zimi i za grijanje. Zimi je potražnja najveća.

Prosječna potražnja prirodnoga plina⁴

Prosječna potražnja za plinom jednaka je odnosu ukupne potrošnje i broja potrošača. Budući je broj priključaka bio iskazan na godišnjoj razini, uzet je njihov linearan raspored po mjesecima da bi se mogla dobiti prosječna mjesečna potražnja. Broj potrošača godine 2002. iznosio je 164 tisuće, 44% više nego godine 1995., kada je bilo 113 tisuća potrošača. Prosječan godišnji rast iznosio je oko 7.200 potrošača. Prosječna je godišnja potrošnja plina smanjena sa 1419 m³ po potrošaču u godini 1995. na 1226 m³ po potrošaču u godini 2002.

Prosječna plaća⁵

Kretanje prosječne plaće također je veoma važna varijabla u potražnji za plinom. Pretpostavlja se da potražnja za plinom raste kada se plaća povećava.

² Podaci o stupanj danima izvedeni su na osnovu podataka o temperaturi.

³ Godišnje izvješće Gradske plinare Zagreb 2000. – 2001.

⁴ Godišnje izvješće Gradske plinare Zagreb, podaci o broju potrošača, 2001.-2002.

⁵ www.dzs.hr

Rast plaća omogućuje veću udobnost građana. Budući da je plin veoma komforan i ugodan energent veoma je vjerojatno da će potražnja za plinom i dalje rasti. Plaće su povećane više nego dvostruko. Godine 1995. prosječna je plaća iznosila oko 2.000 kuna, a do kraja godine 2001. povećana je više od 4.000 kuna. Prosječna je plaća u navedenom vremenskome razdoblju nominalno povećana za 95% ili za 1980 kuna.

Cijena prirodnoga plina za kućanstva⁶

Cijena prirodnoga plina također je jedna od varijabli koju valja uzeti u obzir kada se analizira potražnja za prirodnim plinom. Pretpostavlja se da potražnja pada, kada cijena energenta raste i obrnuto. U promatranome razdoblju od godine 1995., pa do godine 2001. cijena plina je povećana gotovo dvostruko. Na početku godine 1995. cijena plina za jedan prostorni metar u Zagrebu iznosila je oko 1 kunu, a na svršetku godine 2001. metar kubični plina koštao je 1,8 kuna (sa PDV). U promatranom se razdoblju cijena plina mijenjala četiri puta, pa će biti zanimljivo vidjeti kako tako rijetka promjena cijene plina utječe na potražnju za plinom i kakva je elastičnost potrošnje na promjenu cijene. U modelu su primijenjene tekuće cijene plina.


Potrošnja plina i temperatura

Usporedba istovremenog kretanja srednje dnevne temperature i dnevne potrošnje plina za godinu 2002. prikazana je na slijedećem grafu.

⁶ Vuk, B. et al.: "Energija u Hrvatskoj 2000. i 2002.", Godišnji energetske pregled, Ministarstvo gospodarstva, Republika Hrvatska, Zagreb, (poglavlje o cijeni energije).

Graf 1.

DINAMIKA POTROŠNJE PLINA U ODNOSU NA TEMPERATURU




Izvor: Godišnje izvješće Gradske plinare Zagreb za godinu 2002.

Temperatura i potrošnja obrnuto su proporcionalne. Kada je dnevna temperatura velika, dnevna je potrošnja plina mala i obrnuto. Može se zaključiti da je utjecaj dnevne temperature na potražnju za plinom veoma veliki.

Isto je tako zanimljivo uočiti da je u ljetnim mjesecima, svibnju, lipnju, srpnju i kolovozu, potrošnja plina konstantna, bez obzira na vanjsku temperaturu. U tome razdoblju na potražnju za plinom ne utječe dnevna temperatura, jer je ona iznad razine kada njezino povećanje utječe na potrošnju plina. Sezonski karakter potražnje za plinom vidi se i u ostalim mjesecima kalendarske godine. To se najbolje vidi u siječnju i u prosincu, u najhladnijim mjesecima u godini. Kod potražnje za plinom jednako je tako bitan i psihološki utjecaj koji se očituje u tome da se pri jednakim temperaturama u proljeće troši više plina nego u jesen. Razlog je činjenica da je proljeće prestanak sezone grijanja i da se grijanje ne isključuje sve dok ne dođe do određene konstantne vanjske temperature, a jesen je početak sezone grijanja i ljudi bez obzira na pad temperature čekaju da značajnije zahлади da počnu sa sezonom grijanja. Na slijedećem je grafu prikazana srednja dnevna potrošnja u odnosu na vanjsku temperaturu zraka. U analizu su uzeti podaci za godinu 2002. Promatrana je srednja dnevna temperatura određenoga dana i potrošnja plina u tome danu.

Graf 2.

SREDNJA DNEVNA POTRAŽNJA U ODNOSU NA VANJSKU TEMPERATURU ZRAKA



Izvor: Godišnje izvješće Gradske plinare Zagreb za godinu 2002.

Na grafu se vidi da dnevna potrošnja plina pada kada temperatura raste. Kada je temperatura zraka iznad 18 stupnjeva Celzijusa, potrošnja je plina ujednačena. To je potrošnja u tehnološkim procesima koja nije uvjetovana promjenama u vanjskoj temperaturi. Dobijena funkcija pokazuje linearnu povezanost promatranih varijabli.

3. Ukupna potrošnja plina i potrošnja plina po kućanstvu u Zagrebu

Stohastička regresijska funkcija ukupne mjesečne potražnje kućanstava za prirodnim plinom ima oblik

$$Y_i = \alpha + \beta X_i + \varepsilon_i, \quad (1)$$

u kojem Y_i označuje ukupnu mjesečnu potražnju kućanstava za prirodnim plinom u Zagrebu i X_i prosječnu mjesečnu temperaturu zraka u stupnjevima Celzijusa u Zagrebu. Regresijski su koeficijenti α i β , a slučajno je odstupanje ε_i .

Deterministička komponenta stohastičke regresijske funkcije naziva se determinističkom funkcijom ukupne mjesečne potražnje kućanstava za prirodnim plinom. Nju matematički izražavamo zapisom

$$E(y_i/x_i) = \alpha + \beta x_i, \quad (2)$$

Regresijski koeficijent α izražava ukupnu mjesečnu potražnju kućanstava za prirodnim plinom kada je temperatura zraka jednaka nuli, a koeficijent β za koliko se mijenja ukupna mjesečna potrošnja plina kada se temperatura zraka poveća za jedan stupanj.

Stohastičku regresijsku funkciju ukupne mjesečne potražnje kućanstava za prirodnim plinom procjenjujemo regresijskom funkcijom uzorka

$$Y_i = \hat{\alpha} + \hat{\beta} X_i + e_i, \quad (3)$$

u kojoj su $\hat{\alpha}$ = ocjenjivač od α , $\hat{\beta}$ = ocjenjivač od β i e_i = ocjenjivač od ε_i . Stvarne se vrijednosti ocjenjivača nazivaju ocjenama. Regresijsku funkciju uzorka možemo preobraziti tako da dobijemo oblik koji odgovara obliku determinističke regresijske funkcije. On je

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i, \quad (4)$$

gdje je \hat{Y}_i ocjenjivač od $E(y_i/x_i)$. Opažene su vrijednosti ovisne varijable

$$Y_i = \hat{Y}_i + e_i, \quad (5)$$

Ocjenjivači su slučajne varijable. To nam omogućuje da, pošto se uvedu određene pretpostavke o ponašanju stohastičkog člana, testiramo različite pretpostavke o pouzdanosti regresijske funkcije i hipoteze o vrijednostima pojedinačnih koeficijenata regresije.

U našem smo slučaju determinističku funkciju

$$Y_i = \alpha + \beta X_i, \quad (6)$$

u kojoj je X_i prosječna mjesečna temperatura u Zagrebu i Y_i ukupne mjesečne potrošnje plina u Zagrebu procijenili ocjenjivačima

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i, \quad (7)$$

primjenjujući metodu najmanjih kvadrata. Nakon provedenog postupka, dobijeni su ovi rezultati:

$$\begin{array}{ll} \hat{Y}_i = 31267.67 - 1451.07X_i & (8) \\ (737.07) & (54.37) \end{array} \quad \begin{array}{l} \bar{R}^2 = 0.896 \\ F = 712.42 \\ D-W = 1.219 \end{array}$$

Prije svega primjećujemo da dobijene ocjene imaju očekivane predznake i da varijacije prosječne mjesečne temperature objašnjavaju 89.6% varijacija ukupne mjesečne potrošnje plina u zagrebačkim kućanstvima. Veličina F pokazatelja potvrđuje da je ovaj zaključak pouzdan na pet postotnoj razini signifikantnosti.

Ocijenjene standardne greške ocjena regresijskih koeficijenata nalaze se u malim zgradama. Kada se dobijene ocjene regresijskih koeficijenata usporede s ocijenjenim standardnim greškama ocjena, dobivaju se visoke vrijednosti Studentovih pokazatelja: 42.42 i -26.69. To nam pokazuje da možemo tvrditi kako je vjerojatnost da se dobijene ocjene regresijskih koeficijenata razlikuju od nule veoma velika.

Postavlja se pitanje možemo li poboljšati dobijene ocjene uvođenjem dodatne varijable u naš model?

Prva je dodatna varijabla prosječna mjesečna plaća u Zagrebu (X_2). Nakon uvođenja te varijable, dobijena je ocjena:

$$\hat{Y}_i = 23626.85 - 1469.72X_1 + 2.53X_2 \quad (9) \quad \bar{R}^2 = 0.9207$$

(1677.20) (48.37) (0.515)

F= 470.17
D-W=1.559

Dobijene ocjene koeficijenata imaju očekivane predznake. Varijacije prosječne mjesečne temperature i prosječne mjesečne plaće objašnjavaju 92.07% varijacija ukupne mjesečne potrošnje plina u zagrebačkim kućanstvima. Veličina F pokazatelja potvrđuje da je ovaj zaključak pouzdan na pet postotnoj razini signifikantnosti. Kada se ocjene regresijskih koeficijenata usporede s ocijenjenim standardnim greškama ocjena dobivaju se visoke vrijednosti Studentovih pokazatelja: 14.08, -30.55 i 4.94. Možemo tvrditi da je velika vjerojatnost da se dobijene ocjene regresijskih koeficijenata razlikuju od nule.

No, ovdje je važno zapaziti da se koeficijent determinacije u ovome modelu signifikantno ne razlikuje od koeficijenta determinacije u prethodnome modelu i da je razlika između ocjena slobodnoga člana velika. To upućuje na zaključak da specifikacija modela ne opisuje stvarna zbivanja, pa pouzdano možemo vjerovati u ocjenu koeficijenta slobodnoga člana i u ocjenu koeficijenta plaće. Stoga moramo i dalje tragati za modelom koji pouzdanije opisuje stvarnost.

Kao i u prethodnom modelu, jedino D-W pokazatelj ima nepoželjnu vrijednost 1.559 koja nas upozorava da je autokorelacija različita od nule na razini signifikantnosti od 5%, ali je D-W pokazatelj znatno viši.

Uključivanje cijene plina u model prema očekivanju, nije dalo zadovoljavajuće rezultate. Razlog je veoma jednostavan. Promjene cijene plina nisu česte. Uz to, udio izdataka kućanstava za plin u ukupnim je izdacima kućanstava relativno mali, pa se u tim okolnostima i ne može očekivati signifikantan utjecaj tako rijetkih promjena cijena plina na potražnju za plinom. Nepromijenjeni koeficijent determinacije i prihvatljivost hipoteze da se regresijski koeficijent uz tu varijablu signifikantno ne razlikuje od nule samo potvrđuju opravdanost prethodnog izvođenja zaključaka. Dobijeni je rezultat veoma zanimljiv s ekonometrijskoga stajališta, pa ćemo ga navesti bez daljeg komentara.

$$\hat{Y}_i = 24600.93 - 1475.8X_1 + 3.5X_2 - 2841.53X_3 \quad (10) \quad \bar{R}^2 = 0.9214$$

(1994.21) (48.61) (1.183) (3138.39)

F= 313.025
D-W=1,572

Dosadašnja analiza odrednica potrošnje plina u Zagrebu odnosila se na ukupnu mjesečnu potrošnju plina. Pokazatelji koji upućuju na zaključak da bi se specifikacija modela potrošnje plina mogla poboljšati naveli su nas na pomisao da bi model potrošnje plina u kojem je ovisna varijabla, umjesto ukupne mjesečne potrošnje plina, mjesečna potrošnja plina po kućanstvu i u kojem je neovisna varijabla, umjesto prosječne mjesečne temperature u stupnjevima Celzijusa, broj stupanj dana. Vrijednost varijable stupanj dani dobivaju se na slijedeći način:

$(18 - \text{temperatura u stupnjevima Celzijusa}) \times \text{broj dana u mjesecu} = \text{stupanj dani}$

Ako je temperatura 18 stupnjeva Celzijusa ili više, stupanj dani su nula. Ako je npr. temperatura 10 stupnjeva Celzijusa, a mjesec ima 30 dana, tada je:

$$(18-10) \times 30 = 240 \text{ stupanj dana.}$$

Prosječna godina ima između 2700 i 3100 stupanj dana.

Bitno je uočiti da broj stupanj dana raste kada temperatura zraka u stupnjevima Celzijusa pada, odnosno da broj stupanj dana opada kada temperatura zraka raste.

Prednost je stupanj dana to što imaju korektivni faktor od 18 stupnjeva kao granicu, jer potrošači iznad te temperature najčešće ne troše prirodni plin za grijanje. Druga je prednost što se pri obračunu stupanj dana uzimaju u obzir svi dani u mjesecu, a ne samo jedan dan i što se umjesto ukupnoga broja stupanj dana kao varijable upotrebljava prosječan broj stupanj dana.

Stohastička regresijska funkcija prosječne mjesečne potražnje kućanstava za prirodnim plinom ima matematički oblik

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad (11)$$

u kojem Y_i označuje prosječnu mjesečnu potražnju kućanstava za prirodnim plinom u Zagrebu i X_i temperaturu zraka u stupanj dani u Zagrebu.

Ocjenjivanje je mjesečne potrošnje plina po kućanstvu u Zagrebu dalo slijedeće rezultate:

$$\hat{Y}_i = 19.206 + 0.406X_1 \quad (12) \quad \bar{R}^2 = 0.968$$

(2.43) (0.008) **F= 2470.51**
D-W=2.047

Dobijene ocjene imaju očekivane predznake i varijacije prosječne mjesečne temperature objašnjavaju 96.8% varijacija prosječne mjesečne potrošnje plina po kućanstvima. Veličina F pokazatelja potvrđuje da je ovaj zaključak pouzdan na pet postotnoj razini signifikantnosti.

Ocijenjene standardne greške ocjena nalaze se u malim zgradama. Kada se dobijene ocjene usporede sa standardnim greškama ocjena, dobivaju se visoke vrijednosti Studentovih pokazatelja: 7.886 i 49.704. To nam pokazuje da možemo tvrditi kako je vjerojatnost da se dobijene ocjene regresijskih koeficijenata razlikuju od nule i ovoga puta veoma velika. Konačno, D-W pokazatelj ima gotovo idelanu vrijednost 2.047 koja nam pokazuje da je autokorelacija jednaka nuli na razini signifikantnosti od 5%. Veći koeficijent determinacije i gotovo idealna vrijednost D-W pokazatelja, uvjerljivi su dokazi da je specifikacija modela potrošnje plina u kojem su stupanj dani neovisna varijabla, znatno bolja od specifikacije modela u kojem je neovisna varijabla prosječna mjesečna temperatura zraka.

Dodajući prethodnom modelu još jednu varijablu X_2 , cijenu plina u Zagrebu uz prosječnu potrošnju, dobijeni su slijedeći rezultati:

$$\hat{Y}_i = 25.06 + 0.405X_1 - 4.25X_2 \quad (13) \quad \bar{R}^2 = 0.969$$

(8.82) (0.008) (6.19) **F= 1272.39**
D-W=2.058

Ponovno se pokazuje da je cijena plina suvišna varijabla. Njezino uvođenje u model signifikantno ne mijenja prethodno dobijene ocjene, niti utječe na veličinu koeficijenta determinacije. Stoga je dalja rasprava o tome modelu nepotrebna.

Treći i posljednji model uključuje dvije dodatne varijable: cijenu plina, X_2 , i prosječnu plaću, X_3 .

Rezultati su ocjenjivanja:

$$\hat{Y}_i = 25.948 + 0.407X_1 - 20.73 X_2 + 0.0069 X_3 \quad (14) \quad \bar{R}^2 = 0.969$$

(8.81) (0.008) (14.18) (0.0053) **F= 855.8**

Uključivanje dodatnih varijabli u model ne mijenja ni koeficijent determinacije, ni već dobivene ocijene parametara, niti D-W pokazatelj. Dvije dodatne varijable suvišne su.

Zašto su kao varijable suvišne cijena plina i prosječna plaća?

Cijena plina – nije signifikantna zato što se potrošači, zbog malog udjela izdataka za plin u ukupnim izdacima, radije odriču nekog drugog ne tako prijeko potrebnog potrošačkoga dobra kao što je energija, da bi mogli zadovoljiti prijeko potrebne toplinske potrebe u zimi. Promjena cijena u analiziranome razdoblju dogodila se samo četiri puta, pa je elastičnost potražnje na promjenu cijene veoma mala. Plin se u većini slučajeva mora upotrebljavati jer je za grijanje konkurentniji od električne energije, a ostali su energenti u gradu Zagrebu teže dostupni.

Klimatski uvjeti izraženi prosječnom mjesečnom temperaturom ili stupanj danima osnovna su odrednica ukupne i prosječne potrošnje plina. Potrošač je zbog relativno malog udjela izdataka za plin u dohotku uvijek spreman žrtvovati dio dohotka za grijanje, bez obzira na to povećavaju li se ili se smanjuju plaće. Zato kretanje prosječne plaće nije važno za objašnjavanje kretanja potrošnje plina.

4. Zaključak

Potražnja za prirodnim plinom u Hrvatskoj primarno ovisi o srednjoj mjesečnoj temperaturi zraka. Utjecaj ostalih varijabli, cijene energenta za kućanstva i prosječne plaće, znatno su manje signifikantni. Cijena plina nije signifikantna, jer se potrošači odriču nekog drugog ne tako prijeko potrebnog potrošačkoga dobra kao što je energija, da bi mogli zadovoljiti prijeko potrebne toplinske potrebe. Potrošač je također uvijek spreman žrtvovati dio dohotka za grijanje bez obzira na to povećavaju li se ili se smanjuju plaće.

Prednost je prirodnoga plina kao energenta to što je konkurentniji od električne energije, a ostali su energenti u gradu Zagrebu teže dostupni. Značajno je i to da je promjena tehnologije grijanja lakša u dugome roku.

Ekonometrijski modeli u kojima je prosječna mjesečna potrošnja prirodnoga plina ovisna varijabla bolje opisuju stvarnost od modela u kojima je ukupna potrošnja prirodnoga plina ovisna varijabla. Model je moguće koristiti i za procjenu potražnje za prirodnim plinom u budućnosti ovisi o promjeni neovisnih varijabli u modelu.

POPIS LITERATURE

1. Dorsey, W. B. (1997). *Forecasting Peak Demand and Load Shapes, The Integration and Use of Helm, Forecasting in an Era of Marketing, Conversation and Competition*. California, Palo Alto: Electric Power Research Institute, Proceedings of the Sixth EPRI Load-Forecasting Symposium.

2. Državni zavod za statistiku RH (1995.-2001.). *Statistički ljetopisi*. Zagreb.
3. Gradska plinara Zagreb. *Godišnja izvješća* (2001.-2002.), Zagreb.
4. Gujarati, N. D. (1995). *Basic Econometrics*, Third Edition. McGraw-Hill.
5. IEA (1994). *Natural Gas Transportation-Organisation and Regulation*. Paris: OECD.
6. Kmenta, J. (1997). *Počela ekonometrije*, drugo izdanje. Zagreb: Mate d.o.o.
7. Koutsoyiannis, A. (1996). *Moderna mikroekonomika*, drugo izdanje. Zagreb: Mate d.o.o.
8. Mattson, W. (1998). "PG&E's Simplified Approach to Forecasting Residential Gas Sales", Virginia: A.G.A. *Forecasting Review*. American Gas Association.
9. McQuade, O. (1996). *The Future Energy Utility Company: Convergence of natural gas and electricity supply chains*. FT.
10. Naini A., Madduri V. (1998). "Factors Influencing Econometric and End-Use Forecasts: Natural Gas Demand in Alberta", Virginia: A.G.A, *Forecasting Review*, American Gas Association.
11. Pešut, D. et al. (2001). *Masterplan za prirodni plin u Republici Hrvatskoj do 2025. godine*. Zagreb: Energetski institut Hrvoje Požar.
12. Vuk, B. et al. (2000). *Energija u Hrvatskoj*. Godišnji energetske pregled. Zagreb: Ministarstvo gospodarstva, Republika Hrvatska.
13. Vuk, B. et al. (2002). *Energija u Hrvatskoj*. Godišnji energetske pregled. Zagreb: Ministarstvo gospodarstva, Republika Hrvatska.
14. Watson, W.M., Pastuszek, L., Cody, E. (1997). *A comparison of monthly forecasts of commercial electricity sales*. California, Paolo Alto: Electric Power Research Institute, Proceedings of the Sixth EPRI Load-Forecasting Symposium.

ECONOMETRIC MODELLING OF GAS DEMAND

Summary

This paper analyzes econometric modelling of gas demand, monthly household gas demand, it defines function of total and average monthly gas demand of households as dependant variable, according to following independent variables: average month temperature, household's gas price and average salary. Energy and energy demand function are very important for functioning of the economy of every country and for Croatia as well. In the moment when importance of energy is raising more and more, it is interesting to see which factors influence the energy demand. It is also interesting to see importance of every single factor. With regression analysis author defines gas demand function. Conclusion is that gas demand primarily depends on average monthly air temperature and influences of other variables, while household's gas price and average salary, are less important. Author concludes that gas demand is inelastic or less elastic on changes of household's gas price and average salary. Also, econometric models with average gas demand are better and more accurate than models with total gas demand. With given model we can predict future gas demand according to the variation of independent model variables.

Key words: econometric analysis, gas demand function, gas price, average salary, average month air temperature